

SVEUČILIŠTE U SPLITU

EKONOMSKI FAKULTET SPLIT

ZAVRŠNI RAD

**USPOREDNA ANALIZA POKAZATELJA
TURISTIČKE DJELATNOSTI U SPLITSKO-
DALMATINSKOJ ŽUPANIJI PREMA POPISIMA
STANOVNIŠTVA 2001. I 2011. GODINE**

Mentor:

Prof.dr.sc. Elza Jurun

Student:

Mario Vojković

Split, rujan 2015.

SADRŽAJ

| | |
|--|-----------|
| 1. UVOD..... | 2 |
| 2. POPIS STANOVNIŠTVA | 5 |
| 3. TURISTIČKA DJELATNOST U RH..... | 8 |
| 3.1. Turizam | 8 |
| 3.2.1. Razdoblje do Prvog svjetskog rata | 9 |
| 3.2.2. Razdoblje između dva svjetska rata..... | 10 |
| 3.2.3. Razdoblje od Drugog svjetskog rata do 1990. Godine | 11 |
| 3.2.4. Razdoblje najnovije hrvatske povijesti | 12 |
| 4. METODOLOGIJA USPOREDNE STATISTIČKE ANALIZE..... | 14 |
| 4.1. Analiza vremenskih nizova | 14 |
| 4.2. Grafičko prikazivanje i uspoređivanje vremenskih nizova | 15 |
| 4.3. Brojčana analiza vremenskih nizova | 17 |
| 4.3.1. Pokazatelji pojedinačnih apsolutnih promjena | 17 |
| 4.3.2. Osnovni brojčani pokazatelji relativnih promjena..... | 18 |
| 4.4. Individualni indeksi..... | 18 |
| 4.5. Verižni indeksi..... | 19 |
| 4.6. Bazni indeksi | 19 |
| 4.7. Srednje vrijednosti | 20 |
| 4.8. Regresijska analiza..... | 24 |
| 4.8.1. Dijagram rasipanja..... | 24 |
| 4.8.2. Jednostruka linearna regresija | 25 |
| 4.9. Dummy varijable..... | 27 |
| 5. POKAZATELJI TURISTIČKE DJELATNOSTI U SPLITSKO-DALMATINSKOJ ŽUPANIJI PREMA POPISIMA | 31 |
| 6. ZAKLJUČAK..... | 43 |
| SAŽETAK | 45 |
| SUMMARY | 45 |
| LITERATURA | 46 |
| Popis slika | 47 |
| Popis tablica..... | 47 |
| PRILOG..... | 48 |

1. UVOD

Turizam se može definirati kao sektor pa čak po i industrija čiji procesi i aktivnosti omogućuju i osiguravaju sinergijske efekte kroz suradnju ostalih sektora međusobno zahvaljujući turističkim aktivnostima. Turizam zadire u sve konvencionalne sektore gospodarstva, ali i one tzv. nekonvencionalne poput sektora koji osiguravaju društvene, kulturalne, ambijentalne i prirodne sadržaje. Upravo iz tih razloga za turistički se sektor može reći da je on interdisciplinaran po pitanju djelatnosti i potrebe za suradnje s različitim djelatnostima ostalih sektora gospodarstva. Bit turizma, kao društvene i ekonomske pojave, proizlazi iz različitih veza unutar društvenih i ekonomskih odnosa koje čovjek uspostavlja radi zadovoljenja turističkih potreba¹.

Turizam je jedna od najznačajnijih gospodarskih grana u Hrvatskoj. Turizam omogućuje „izvoz“ proizvoda i usluga u zemlji. Osigurava rast prelijevanjem kapitala iz drugih zemalja. Osnova hrvatskog turizma jest ponuda sunca, mora i pijeska. Iako imamo odlične predispozicije za to to ne znači da se čitavi sektor treba ostavit na takvoj razini ponude. Važno je ulaganje u raznolikost ponude razvojem različitih selektivnih oblika turizma poput rekreativnog, kongresnog i sl. Zadnjih godina u tom se sektoru događaju brojne promjene od ekonomskih (kriza) do trendova promjena u potražnji. Do tih promjena dolazi iz više razloga. Jedan od njih su i svjetske demografske promjene, a potom dolazi i do porasta svijesti o zdravom životu kao i razvoja potrebe za očuvanjem, isticanjem i upoznavanjem lokalnih tradicionalnih načina življenja i vrijednosti kao protuteze sve većoj svjetskoj globalizacijskoj uniformnosti. Sve to postavlja pitanje održivog turizma. Održivost postaje značajan čimbenik i u smislu očuvanja lokalne kulture, ali i očuvanja lokalnog okoliša turističkih destinacija.

Hrvatski turistički sektor sudjeluje u BDP-u i do 15%. Kako se kreću osnovni pokazatelji sektora turizma te što ih naviše definira problematika je kojoj se bavi ovaj rad. Cilj rada je prezentirati razvoj turističkog sektora Hrvatske tijekom vremena kako bi se uočile značane promjene. Analiza pokazatelja turističkih dolazaka i noćenja osnovna su dva pokazatelja

¹ Petrić, L., Osnove turizma, Ekonomski fakultet Split, Split, 2003., str. 25.

trendova. Dodatno će se uz analizu dolazaka i noćenja uključiti i pokazatelji čitavog gospodarstva inflacije i tečaja ali i doprinosa turističkog sektora kreaciji BDP-a kroz devizni prihod od turizma te investicija turističkog sektora kako bi se uočile relacije odnosa tih pokazatelja što će ukazati na ulogu međusektorske suradnje gospodarstva. Rad se sastoji od dva osnovna dijela: teorijskog i praktičnog.

Pojava financijske krize 2008. pritišće sve pa tako i turistički sektor koji počinje bilježiti negativna turistička kretanja na globalnoj razini, koja se nastavljaju i u 2009. godini kada se bilježi prvi pad nakon šestogodišnjeg trenda rasta. U 2010. godini turistički se promet oporavlja što se nastavilo do danas.

Iako je financijska kriza Hrvatsku pogodila snažno te se gospodarstvo još uvijek bori s posljedicama ako se promotre kretanja u turističkom sektoru od početka krize tada se uviđa da je hrvatski turistički sektor pokazao snagu i stabilnost. Usprkos popriličnoj snazi turističkog sektora na makro razini kretanje pojedinih subjekata turističkog sektora poput hotela i pojedinih destinacijskih područja tada se uočava da se brojke ne mijenjaju previše što dodatno ukazuje na snagu i potencijal Hrvatske kao destinacije i hrvatskog turizma.

Hrvatski je turizam u vrijeme krize glavni nositelj aktivnosti koji popravljaju ukupnu bilancu. Kod nas je, kao i u mnogim zemljama u čijim ekonomijama ima značajan udio, upravo turizam bio osnovni motor koji pokreće gospodarstvo i u periodu krize. Glavni ekonomski učinci turizma proizlaze iz pritjecanja stranih valuta, jačanja državnih prihoda, zaposlenosti i dohotka, te poticanja regionalnog razvitka. Prva dva učinka primjećuju se na nacionalnoj dok su ostali na nižim razinama. Svi učinci su, dakako povezani, ali ih je u analizi potrebno odvojeno promatrati.

Na temelju prezentiranog se uočava problematika rada. Fokus problematike je na kretanje pokazatelja turističkog sektora kroz analizu broja dolazaka i broja noćenja na području Splitsko dalmatinske županije te efekti turističke aktivnosti na gospodarstvo i trendove županije. Kako bi se istražila predstavljena problematika važno je definirati predmet istraživanja. Predmet istraživanja su vremenski nizovi broja dolazaka i noćenja kao glavni

pokazatelji turističke aktivnosti. Kako bi se oni povezali s cjelokupnim gospodarstvom te kako bi se uočila povezanost turističkog s ostalim sektorima te se uvidjeli efekti uz njih su izabrani i pokazatelji turističkog prometa, tečaja domaće valute za euro i dolar, pokazatelji inflacije, stope nezaposlenosti, BDP te investicija u turistički sektor. Izabrani pokazatelji osigurali su cjelovitu analizu efekata i odnosa turističkog sektora s ostalim gospodarskim sektorima ali i utjecaja i doprinosa ukupnom razvoju i kreiranju dodane vrijednosti BDP-u od strane turističkog sektora.

Cilj rada je prezentiranjem problematike te empirijskom analizom definiranih varijabli ukazati na poziciju te ulogu turističkog sektora u RH s naglaskom na SD županiju i njezin doprinos gospodarskoj aktivnosti na makro razini. Analiza trendova turističkog sektora će ukazati na osjetljivost turizma na pritiske krize dok će regresijski modeli definirati odnose i veze turističkog i ostalih gospodarskih sektora što će biti podloga za definiranje smjernica strategija održivog turizma te smanjenja sezonalnosti turizma.

Kako bi se obradila definirana problematika preko predmeta istraživanja koristit će se različite metode u skladu s teorijskim i praktičnim dostignućima koja će se prezentirati u radu. U teorijskom će se dijelu nastojati pojasniti uloga glavnih faktora te će se prezentirati povijest razvoja turističkog sektora u glavnim vremenskim etapama. U praktičnom će se dijelu analizirati kretanje osnovnih pokazatelja turističke aktivnosti primjenom statističkih metoda. Rad završava zaključkom koji daje osvrt na rezultate. Metode korištene za prikupljanje, pripremu i obradu podataka koji su inputi ovom radu su: metoda kauzalne indukcije (koja će ukazati na razlike između uzroka i posljedica), metoda klasifikacije (kojom će se osigurati razvrstavanje pojava i predmeta radi njihove preglednosti), komparativna metoda (za usporedbu pokazatelja kroz vrijeme). Prikupljeni podaci će se prikazati, analizirati i uspoređivati primjenom različitih statističkih metoda poput izračuna srednjih vrijednosti, analize trenda, korelacije te regresije.

2. POPIS STANOVNIŠTVA

Popis stanovništva, kućanstava i stanova je najveće statističko istraživanje kojem je cilj prikupiti osnovne podatke o broju, teritorijalnom rasporedu i sastavu stanovništva prema njegovim demografskim, ekonomskim, obrazovnim, migracijskim i ostalim obilježjima. Popisom se, također, prikupljaju i podaci o kućanstvima i stanovima te njihovim obilježjima. Popis je najopsežniji izvor podataka o stanovništvu, kućanstvima, obiteljima i stanovima. Ti su podaci nužni za provedbu raznih gospodarskih i socijalnih razvojnih politika te znanstvenih istraživanja.

Popis stanovništva priprema, organizira i provodi Državni zavod za statistiku, a u okviru svojih nadležnosti sudjeluju i Državna geodetska uprava, Ministarstvo vanjskih poslova i europskih integracija, Ministarstvo unutarnjih poslova, Ministarstvo obrane i Ministarstvo pravosuđa. Radi pripreme, organizacije i provedbe Popisa stanovništva osnivaju se i druga tijela kao što su županijska popisna povjerenstva, popisna povjerenstva ispostava za područje gradova i općina i popisni centri za područje dijela grada ili općine.

Glavne zadaće Državnog zavoda za statistiku su sljedeće²:

- izrada Metodologije za pripremu, organizaciju i provedbu Popisa te definiranje sadržaja i izgled svih popisnih obrazaca
- pravodobno i potanko obavješćivanje stanovništva o cilju, značenju i sadržaju Popisa
- izrada uputa za sudionike u Popisu (povjerenstva, koordinate, instruktore, kontrolore i popisivače) i nadzor njihove jedinstvene primjene
- imenovanje koordinatora, instruktora i kontrolora za županije i Grad Zagreb
- organiziranje i nadziranje stručno-metodološkog osposobljavanja članova povjerenstava i instruktora
- pružanje stručno-metodološke pomoći povjerenstvima u pripremi i provedbi Popisa

² <http://www.dzs.hr/Hrv/censuses/census2011/censusfaq.htm>

- organizacija tiskanja i razdiobe osnovnih i pomoćnih popisnih obrazaca, uputa i predviđenog pribora te oglednih primjeraka osnovnih popisnih obrazaca na jezicima i pismu nacionalnih manjina
- preuzimanje ispunjenih obrazaca nakon popisivanja
- obavljanje kontrole, ručne i strojne pripreme popisne građe za obradu
- odluka o izboru tehnologije unosa i obrade podataka na računalu
- obrada podataka dobivenih popisom i objava prvih i konačnih rezultata popisa
- planiranje i raspored financijskih sredstava za organizaciju, provedbu popisivanja, obradu podataka te publiciranje i diseminaciju podataka.

U Republici Hrvatskoj, kao i u većini europskih zemalja, provodi se svakih 10 godina, a popisuju se tri jedinice: stanovništvo, kućanstva i stanovi.

Prvi djelomični popisi stanovništva na području današnje Republike Hrvatske provedeni su 1746. godine i 1754. godine, u doba vladavine Marije Terezije. Ti popisi nisu obuhvatili cijelo stanovništvo. Izostavljeno je plemstvo i svećenstvo. Stanovništvo je popisivano prema pripadnosti posjeda pojedinom vlastelinu ili gradu. Popis 1785. godine, proveden je za vrijeme vladavine Josipa II., također je bio nepotpun, bez uključivanja svećenstva. Slijedi također nepotpuni Popis 1805. godine, bez svećenstva, plemića i vojske. Popis 1850./1851. godine također nije bio zadovoljavajući jer se zbog tadašnjih prilika provodio dvije godine³.

Prvi sveobuhvatan popis proveden je 1857. godine u tadašnjoj Austriji, i tek nakon tog popisa postoje podaci za cijelo područje današnje Republike Hrvatske. Nakon toga su slijedili redoviti popisi 1869. godine, 1880. godine, 1890. godine, 1900. godine i 1910. godine.

Između Prvog i Drugoga svjetskog rata u Kraljevini Jugoslaviji provedena su dva popisa, 1921. godine i 1931. godine. Popis 1941. godine nije proveden zbog rata. Nakon Drugoga svjetskog rata u Republici Hrvatskoj provedeno je sedam popisa stanovništva. Prvi je proveden 1948. godine. Bio je to tzv. kratki popis, s glavnim ciljem da se nakon rata utvrdi

³ <http://www.dzs.hr/Hrv/censuses/census2011/censusfaq.htm>

brojno stanje i teritorijalni raspored stanovništva. 1953. godine proveden je kompletan popis radi povećanih potreba za dodatnim informacijama o stanovništvu⁴.

Od 1961. nadalje popis se u Republici Hrvatskoj provodi redovito u desetogodišnjim razmacima (1961., 1971., 1981., 1991. i 2001.).

⁴ <http://www.dzs.hr/Hrv/censuses/census2011/censusfaq.htm>

3. TURISTIČKA DJELATNOST U RH

3.1. Turizam

Turizam je skup odnosa i pojava koje proizlaze iz putovanja i boravka posjetitelja nekog mjesta, ako se tim boravkom ne zasniva stalno prebivalište i ako s takvim boravkom nije povezana nikakva njihova gospodarska djelatnost (Hunziker i Krapf, 1942).

Turistička kretanja se dijele na vrste i specifične oblike turizma. Vrste turizma su definirane određenim kriterijem npr. prema trajanju boravka turista (boravišni, vikend i izletnički turizam), specifični oblici turizma obilježeni su specifičnim turističkim motivom koji posjetitelje privlači u određene destinacije.. Specifični oblici turizma orijentirani su na manje segmente turističke potražnje, a nastali su kao suprotnost masovnom turizmu.

Vrste turizma definiraju se zbog potreba statističkog evidentiranja. Upravo prema statističkom kriteriju izvršena je podjela vrsta turizma i to ovisno o porijeklu turista i zemlji koju posjećuje.

Prema tim kriterijima postoje⁵:

- Domaći – npr. stanovnici RH putuju po RH,
- Ulazni – stanovnici Slovačke putuju i borave u RH,
- Izlazni – npr. stanovnici RH putuju i borave u Slovačkoj.

Cilj svake zemlje je povećati broj dolazaka domaćih i stranih turista (domaći i ulazni turizam) i smanjiti svoj izlazni turizam, tj. broj svojih rezidenata u inozemstvu. Time se žele povećati prihodi i smanjiti rashodi po osnovi turističkih putovanja.

3.2. Razvoj turizma u Hrvatskoj

Razvoj turizma u Hrvatskoj podijeljen je u četiri faze. To su⁶:

- razdoblje do Prvog svjetskog rata
- razdoblje između dva svjetska rata

⁵ Lickorish, L., J., Uvod u turizam, Ekokon, Split, 2006., str. 25.

⁶ Boris Pirjevec, Ekonomska obilježja turizma, Golden marketing, 1998., str 31.

- razdoblje od Drugog svjetskog rata do 1990. godine
- razdoblje najnovije hrvatske povijesti

3.2.1. Razdoblje do Prvog svjetskog rata

Organizirani oblici turizma, odnosno djelovanja turističkih organizacija, postoje u našoj zemlji već više od jednog stoljeća⁷. Prva turistička društvena organizacija osnovana je na Hvaru 1868. godine i prva je takva u našoj zemlji. Oko 1850. godine dolazi do razvoja znatizelje za pojavom turizma. Građani pomalo dobivaju svijest o koristima koje gosti donose. Tako nastaju prvi ugostiteljski objekti u lokalnom vlasništvu. Također nastaju turistička mjesta – lječilišta na Jadranu. No prije svega, turistički se promet počeo prvotno razvijati u kontinentalnom području, u mjestima s mineralnim izvorima koja su postepeno postala lječilišta, a zatim kupališta. spominjali su se Opatija, Crikvenica, Lovran, Selca, Novi Vinodolski, Kraljevica, Rab, Lošinj, Malinska itd, a svi gradovi zadržavaju popularnost do današnjih dana.

Tek krajem XIX. stoljeća primorska mjesta počinju interesirati turiste i to ne za ljetovanje, već za zimovanje. U Hrvatsku ulazi strani kapital i izgrađuje se željeznička mreža. Razvijaju se društvene turističke organizacije. Tako neka mjesta određuju da svoj opći razvoj u budućnosti vide kroz razvoj turizma.

Turizam u vrijeme prije Prvog svjetskog rata karakterizira⁸:

- država u pravilu ne posvećuje nikakvu pažnju turizmu, ni njegovom razvitku
- bogati ljetuju u toplicama, a zimuju u primorskim mjestima
- potpuna sloboda kretanja, bez putovnica
- razvoj i snaga turizma počiva na entuzijazmu lokalnih turističkih društvenih organizacija

⁷ Lickorish, L., J., Uvod u turizam, Ekokon, Split, 2006., str. 17.

⁸ Boris Pirjevec, Ekonomska obilježja turizma, Golden marketing, 1998., str 34.-36.

| Mjesto | Godina | | Indeks 1910/1897 |
|---------------------|--------|--------|------------------|
| | 1897. | 1910. | |
| Krapinske toplice | 444 | 5.137 | 1.157 |
| Varaždinske toplice | 933 | 1.222 | 131 |
| Lipik | 2.024 | 3.051 | 151 |
| Topusko | 758 | 4.511 | 595 |
| Ukupno | 4.159 | 13.921 | 335 |

Slika 1: Broj turista u nekim primorskim mjestima 1897. i 1910. godine

Izvor: Boris Pirjevec, Ekonomska obilježja turizma, Golden marketing, 1998., str 34.

U navedenih 13 godina se povećao turistički promet i bilježimo početke razvitka turističkog prometa u primorskim mjestima. Od svih primorskih mjesta treba posebno izdvojiti Opatiju u kojoj je do I.svjetskog rata sagrađeno više od 80% svih smještajnih kapaciteta.

3.2.2. Razdoblje između dva svjetska rata

Nakon Prvog svjetskog rata turizam u Hrvatskoj sve više dobiva na značenju te ostvaruje do tada svoj najveći rast. Turistički posjetitelji su uglavnom stranci, te se više od 80 % inozemnog prometa odnosi na posjetitelje iz: Austrije, Njemačke, Italije, Engleske, Čehoslovačke i Mađarske.

Zanimljivo je da već 1929. Godine inozemni turisti preuzimaju primat i u turističkom prometu sudjeluju sa 52%. Konstantni porast turističkog prometa trajao je sve do 1938. godine, kad doseže kulminaciju, i upravo je ta godina baza za sve usporedbe s turizmom nakon rata. Taj podatak, uz gotovo 3 milijuna noćenja turista, 1938. po prvi put izaziva interes države i krupnog kapitala, tako da su glavna obilježja međuratnog turizma Hrvatske sljedeća⁹:

- država se počinje zanimati za turizam, poglavito njegove ekonomske koristi
- turizam se nastoji regulirati, odnosno unaprijediti državnim uplitanjem
- još uvijek putuje samo bogati sloj društva
- hotelski kapaciteti u pravilu su u stranom vlasništvu
- rad i djelovanje lokalnih društvenih organizacija dobiva punu afirmaciju
- 1926. prvi puta ostvareno preko milijun noćenja

⁹ Boris Pirjevec, Ekonomska obilježja turizma, Golden marketing, 1998., str 37.

- Hrvatska raspolaže sa više od 40 000 postelja

| Domaći | | Inozemni | | Ukupno | |
|-------------------|--------------|-------------------|--------------|-------------------|--------------|
| Broj posjetitelja | Broj noćenja | Broj posjetitelja | Broj noćenja | Broj posjetitelja | Broj noćenja |
| 195.000 | 1.300.000 | 104.608 | 1.419.939 | 399.608 | 2.719.939 |
| 48,8% | 47,8% | 51,2% | 52,2% | 100,00% | 100,00% |

Slika 2: Turistički promet u Hrvatskoj 1938.godine

Izvor: Pirjevac B., Ekonomska obilježja turizma, Golden marketing, Zagreb, 1998, str 37.


3.2.3. Razdoblje od Drugog svjetskog rata do 1990. Godine

Za vrijeme Drugog svjetskog rata turistički promet se smanjuje te turizam nije bio prisutan u pravom smislu. Drugi svjetski rat uništio je gotovo sve turističke kapacitete u Hrvatskoj, procjenjuje se da je tek oko 20% kapaciteta bilo spremno za primanje gostiju neposredno nakon rata. Ulaže se u obnovu, ali ona ide sporo, tako da i 10 godina nakon rata 23% soba nema ni tekuću vodu, a samo 4% kupaonicu¹⁰.

Hrvatska se polako počela oporavljati, te je u ovom razdoblju ostvarila svoj vrhunac u turizmu. Zabilježeni su vrlo dobri rezultati u razvoju turizma što se tiče broja kapaciteta, noćenja i broja posjetitelja, dok je turistički promet konstantno bio u porastu. No ova kvantiteta ne jamči nužno i kvalitetu turističke ponude. Identitet Hrvatske kao turističke zemlje sveden je na minimum. Kapaciteti koji su se gradili su najčešće bili kampovi koji su privlačili turiste niže platežne moći. To je pridonijelo poimanju Hrvatske kao „jeftine“ turističke destinacije, koja sve više zaostaje u odnosu na europska turistička kretanja. Što se pozitivne strane tiče, izgrađen je velik broj hotelskih objekata i kampova, sa prosječnim godišnjim rastom kapaciteta od nevjerojatnih 11,4% (od 1965-1975). Ipak, taj postotak kasnije opada i u periodu 1980.-1990. iznosi tek 2%.

¹⁰ Boris Pirjevec, Ekonomska obilježja turizma, Golden marketing, 1998., str 37.- 40.

Kretanje registriranog turističkog prometa u Hrvatskoj 1960.- 2001. godine



Slika 3: Kretanje registriranog turističkog prometa u RH 1960.-2001.


Izvor: BIST – sustav poslovne inteligencije u turizmu

3.2.4. Razdoblje najnovije hrvatske povijesti

U razdoblju od 1991. do 1995. godine Hrvatska se nalazila u Domovinskom ratu te je turizam bilo nemoguće razvijati u tom razdoblju. U 1995. godini, kao zadnjoj ratnoj godini, u Hrvatskoj je zabilježeno 2,4 mil. dolazaka turista, što je 29% manje nego 1994. godine¹¹.

Karakteristično za 1995. godinu jest činjenica da je to zadnja godina u kojoj je, u strukturi dolazaka turista zabilježen poprilično mali udio dolazaka stranih turista, svega 54%. Od 1996. započinje ponovno oživljavanje turizma i obnova devastiranih objekata. počinje se otvarati emitivno tržište srednje i istočne Europe, što potpomaže ponovnom oživljavanju masovnog turizma. Uništeni smještajni kapaciteti za vrijeme rata se polako počinju vraćati na prijeratno stanje, no njihova je iskorištenost slaba. Na europskom emitivnom tržištu se provodi promotivna kampanja s ciljem stvaranja kvalitetnog imidža Hrvatske kao turističke destinacije, rezultat čega je proglašenje Hrvatske najpoželjnijom turističkom destinacijom 2005. godine od strane Lonely Planeta .

¹¹ Ibidem



Slika 4: Dolasci turista u RH u razdoblju od 1975. do 2009. godine

Izvor: Ministarstvo turizma

Na grafu vidimo da dolasci turista u Hrvatsku konstantno umjereno rastu u razdoblju od 2000. Do 2009. godine. U 2002. godini zabilježeno je 8,3 mil. dolazaka turista i u razdoblju od 1994. godine do 2002. godine ukupan broj dolazaka turista rastao je po prosječnoj stopi od 10,8%, s tim da je za dolaske stranih turista ta stopa iznosila 13,5%, a za domaće turiste 2,5%. Hrvatska se već 2005. približila broju turista iz 1985. te broj postelja u odnosu na 1985. je premašen za nekih 100 tisuća. U 2005. godini u Hrvatskoj je boravilo 10 milijuna turista ili 6% više nego godinu prije.

Najviše dolazaka zabilježeno je 2008. godine kad je boravilo 11,3 milijuna turista (točnije 11.260.807) tj. 1% više nego prethodne godine. U 2009. zabilježeno je 10.934.474 ukupnih dolazaka što je za 2,9% manje nego 2008. godine. Domaćih dolazaka u hrvatskim turističkim odredištima bilo je oko 15% manje nego 2008. što se djelomice objašnjava krizom i smanjenjem kupovne moći, djelomice povoljnim cijenama u konkurentskim zemljama. S druge strane, strani su turisti u hrvatskom turizmu 2009. činili 85% ukupnih dolazaka, po čemu se Hrvatska također razlikovala od ostalih zemalja, te je time pojačala svoj udjel i konkurentnost u europskom međunarodnom turizmu.

4. METODOLOGIJA USPOREDNE STATISTIČKE ANALIZE

Statističke metode predstavljaju opće znanstvene metode, korištene ne samo kod prirodnih znanosti (fizika, kemija i dr.) nego i društvenih (ekonomija, sociologija i dr.). Ovim se metodama kvalitativno i kvantitativno istražuju masovne pojave preko djelatnosti (faza) kao što su promatranje, grupiranje, analiziranje i interpretiranje dobivenih rezultata istraživanja. U ovom radu je korišten tek dio metoda koje su bile prikladne za tip, strukturu i obuhvat istraživanja te ciljeve. Korištene tehnike i testovi su: prikaz rezultata preko dvostrukih statističkih tablica, grafički prikaz rezultata ankete, srednje vrijednosti izabranih numeričkih varijabli, analiza varijance, testiranje hipoteza, jednostavna regresija te neparametrijski testovi. Navedeni testovi će biti detaljnije objašnjeni u nastavku.

4.1. Analiza vremenskih nizova

Analiza vremenskih nizova treba omogućiti donošenje brojčanih sudova o obilježjima razvoja pojava u vremenu.

Zadaće takve analize su¹²:

- opis razvoja pojave u vremenu,
- objašnjenje varijacije pojave u vremenu pomoću drugih pojava,
- predviđanje razvoja pojave,
- kontrola procesa.

Predmetom analize može biti jedna pojava ili više njih. U analizi pojave u vremenskoj domeni pomoću modela postoje dva pristupa. Prvi se sastoji u utvrđivanju analitičkih izraza kojima se statistički opisuje razvoj *razine* pojave u vremenu i to pomoću neke funkcije vremena. Vrijednosti funkcije vremena zamjenjuju originalne vrijednosti niza kao što aritmetička sredina zamjenjuje niz pojedinačnih vrijednosti numeričke varijable. Drugi pristup proizlazi iz težnje da se statistički opiše *dinamička struktura* pojave, a ne kretanje njezine razine u vremenu. Ovdje se govori o mjerenju stupnja i smjera korelacije članova iste serije razmaknutih za jedno ili više razdoblja te analitičkog izražavanja takve međuovisnosti.

¹² Rozga, A., Statistika za ekonomiste, Ekonomski fakultet Split, Split, 2009., str. 36.

Prije prijelaza na brojčanu analizu poželjno je niz prikazati grafički. Grafički prikaz je značajno pomoćno sredstvo za zapažanje karakteristika vremenske pojave, a time i sredstvo za izbor prikladnog modela.

4.2. Grafičko prikazivanje i uspoređivanje vremenskih nizova

Grafičkim prikazom vremenskih nizova postiže se jasnija i preglednija slika kretanja vrijednosti promatrane pojave kroz vrijeme. Slika grafikona, kao i svi prikazi u statistici, mora biti jasna i potpuna. Kod vremenskih nizova vrijeme se uvijek nanosi na apscisu, dok se na ordinatu nanose vrijednosti pojave Y_t . Grafički prikaz treba imati sve potrebne oznake: naslov grafikona, izvor grafikona, oznake na ordinati, oznake na apscisi i kazalo ako se na istom grafikonu prikazuje više različitih vremenskih nizova. Na jednom grafičkom prikazu može se uspoređivati više vremenskih nizova s istom jedinicom mjere. Broj vremenskih nizova na jednom grafikonu ograničen je samo zbog tehničkih mogućnosti, jer kod velikog broja nizova uspoređivanje postaje nepregledno. To su grafikoni s aritmetičkim mjerilom na osi ordinata. Postoje grafikoni s logaritamskim mjerilom na osi ordinata. Oni omogućuju prikazivanje i uspoređivanje vremenskih nizova s različitom jedinicom mjere na istom grafikonu. Ovim grafikonom mogu se prikazivati i uspoređivati i vremenski nizovi s istom mjernom jedinicom, ali koji imaju velike razlike među vrijednostima pojave.

Njihova konstrukcija danas je olakšana u raznim statističkim paketima za računalo (Statistica, SPSS i slično).

Ako je omjer najveće i najmanje frekvencije vremenskog niza:

$Y_{\max}/y_{\min} < 10$ - dovoljan jedan logaritamski ciklus,

$10 < Y_{\max}/Y_{\min} \leq 100$ - dovoljna dva logaritamska ciklusa,

$100 < Y_{\max}/Y_{\min} < 1000$ - dovoljna su tri logaritamska ciklusa,

... itd.

Karakteristika logaritamske skale na osi ordinata je da se za vrijednost s kojom počinje 1 logaritamski ciklus uvećava svaka sljedeća vrijednost u ciklusu. S vrijednošću kojom završava 1. logaritamski ciklus počinje drugi i uvećavanje na skali se sada nastavlja s tom veličinom i tako dalje.

Intervalni vremenski nizovi mogu se prikazivati¹³:

- linijskim grafikonom,
- površinskim grafikonom (obično su to stupci, koji su naslonjeni jedan na drugi jer vrijeme teče kontinuirano).

Kod linijskog grafikona za intervalne vremenske nizove (koji prikazuju vrijednost pojave u vremenskim intervalima) vrijednost pojave se nanosi na sredinu svakog promatranog razdoblja (mjesec, kvartal, godina i slično.)

Stupci površinskog grafikona naslonjeni su na os apscisu, imaju jednake baze, a visina im odgovara vrijednostima vremenskog niza za određeno razdoblje. Dakle, površine ovih stupaca su proporcionalne vrijednostima niza, a razlike u njihovoj veličini upućuju na apsolutne razlike vrijednosti promatranih razdoblja.

Ako intervalni vremenski niz prikazuje vrijednosti pojave za različite jedinice vremena, kod grafičkog prikaza radi se aproksimacija kojom se računaju prosječne vrijednosti pojave za manju ili veću vremensku jedinicu. Na primjer, ako jedan niz tvore godišnji i mjesečni podaci, onda se sve svodi ili na godišnje ili na mjesečne vrijednosti pojave ($Y_{mjes.} = Y_{god.} / 12$, jer godina ima 12 mjeseci).

Trenutačni vremenski nizovi mogu se prikazivati linijskim grafikonom. Kod linijskog grafikona za trenutačne vremenske nizove (koji prikazuju vrijednost pojave u trenutku vremena) vrijednost pojave se nanosi u trenutku mjerenja vrijednosti promatrane pojave (početak, sredina, kraj ili neki drugi precizan datum izabranih vremenskih razdoblja) i ovdje se za nizove čije točke promatranja u vremenu nisu jednako udaljene ne treba vršiti korekcija vrijednosti pojave.

¹³ Ibidem, str. 21.-25.

Ako su na ordinati sve vrijednosti (Y_t) promatranog vremenskog niza jako velike dozvoljeno je napraviti vodoravan prekid grafikona na ordinati, na način da se apscisa približi tim velikim vrijednostima niza prema gore, da bi se izbjegao prazni prostor na grafu. Ovaj vodoravan prekid grafikona može se napraviti samo za linijski grafikon.

Okomiti prekid grafikona radi se na apscisi, ako nisu poznate vrijednosti vremenskog niza za sva promatrana vremenska razdoblja (na primjer, ratne godine).

4.3. Brojčana analiza vremenskih nizova

Grafički prikazi omogućavaju stjecanje osnovne slike o dinamici jedne pojave ili više njih. Međutim, u većini slučajeva, uz grafičku analizu, potrebno je provesti i brojčanu analizu kako bi se lakše zaključilo o razvoju pojava u vremenu. Dinamika vremenskog niza može se promatrati preko apsolutnih i relativnih pokazatelja.

4.3.1. Pokazatelji pojedinačnih apsolutnih promjena

Pojedinačne apsolutne promjene od razdoblja do razdoblja računaju se tako da se od vrijednosti pojave u tekućem razdoblju oduzme vrijednost pojave u prethodnom razdoblju¹⁴:

$$\square Y_t = Y_t - Y_{t-1} \quad t = 1, 2, 3, \dots, n$$

Pojedinačne apsolutne promjene u tekućem razdoblju u odnosu prema nekom baznom razdoblju dobivaju se tako da se od vrijednosti pojave u tekućem razdoblju oduzme vrijednost pojave u baznom razdoblju¹⁵:

$$Y_t = Y_t - Y_b \quad t = 1, 2, 3, \dots, n$$

Međutim, pokazatelji apsolutnih promjena nisu uvijek najprikladniji način proučavanja promjena pojave, naročito ako se uspoređuje dinamika pojava koje imaju različite jedinice mjere. U takvim slučajevima koriste se pokazatelji relativnih promjena.

¹⁴ Ibidem, str. 263.

¹⁵ Ibidem

4.3.2. Osnovni brožčani pokazatelji relativnih promjena

Pojedinačne relativne promjene u uzastopnim vremenskim razdobljima mogu se izračunati tako da se vrijednost pojedinačnih apsolutnih promjena od razdoblja do razdoblja podijeli s vrijednošću pojave u prethodnom vremenskom razdoblju. Na taj se način dobije mjera koja se naziva *koeficijent dinamike*:

$$K_t = \frac{\Delta Y_t}{Y_{t-1}}$$

Pojedinačna stopa promjene iz razdoblja u razdoblje dobiva se tako da se koeficijent dinamike pomnoži sa 100. Tako se može saznati za koliko su se postotaka promijenile pojave u tekućem razdoblju u odnosu na prethodno razdoblje:

$$S_t = K_t \cdot 100$$

Stopa promjene u tekućem u odnosu na bazno razdoblje dobivaju se na sljedeći način¹⁶:

$$S_t^* = \frac{\Delta Y_t^*}{Y_b} \cdot 100$$

4.4. Individualni indeksi

Indeksi su relativni brojevi koji su vrlo prikladni za uspoređivanje i upoznavanje dinamike pojava, razlikuju se *individualni* i *skupni*. Indeksi koji pokazuju odnos između dva stanja jedne određene pojave zovu se individualni indeksi, dok se skupnim indeksima mjeri dinamika skupine pojava koje obično imaju neku zajedničku karakteristiku koja ih povezuje u skupinu. Individualni indeksi dijele se na *veržne* i *indekse na stalnoj bazi (bazne)*

¹⁶ Rozga, A., Statistika za ekonomiste, Ekonomski fakultet Split, Split, 2005., str.275.

4.5. Verižni indeksi

Verižni indeksi pokazuju relativne promjene pojave u tekućem razdoblju u odnosu na prethodno razdoblje:

$$V_t = \frac{Y_t}{Y_{t-1}} \cdot 100 \quad t = 1, 2, 3, \dots, n$$

Verižni indeksi uvijek su pozitivni brojevi, a mogu biti sto, veći od sto ili manji od sto, ovisno o veličini uzastopnih frekvencija. Verižni indeks V_t pokazuje koliko jedinica pojave u vremenu t dolazi na svakih 100 jedinica pojave u vremenu $(t-1)$.

Stopa promjene u uzastopnim vremenskim razdobljima može se dobiti iz verižnih indeksa na sljedeći način:

$$S_t = V_t - 100$$

Grafikon verižnih indeksa razlikuje se od standardnog linijskog grafikona. Baznu liniju predstavlja linija 100. Na toj liniji nalazi se aritmetičko mjerilo za vrijeme, a na osi ordinata aritmetičko mjerilo za indekse. Indeksi se prikazuju dužinama koje se samostalno oslanjaju na baznu liniju i čiji nagib ovisi o veličini indeksa.

4.6. Bazni indeksi

Bazni indeksi pokazuju relativne promjene u tekućem razdoblju u odnosu na neko odabrano bazno razdoblje. Indeksi na stalnoj bazi dobivaju se tako da se svaka frekvencija niza podijeli baznom frekvencijom i omjer pomnoži sa sto¹⁷:

$$I_t = \frac{Y_t}{Y_b} \cdot 100$$

Budući da se frekvencije niza dijele istim brojem, bazni indeksi proporcionalni su veličinama iz kojih su izračunati. Bazni indeksi uvijek su pozitivni brojevi. Oni su jednaki sto, veći ili manji od sto, ovisno o frekvencijama danog i baznog razdoblja. Bazni indeks I_t pokazuje

¹⁷ Rozga, A., Statistika za ekonomiste, Ekonomski fakultet Split, Split, 2005., str.279.

koliko jedinica pojave u vremenu t dolazi na svakih sto jedinica pojave u razdoblju b. Stopa promjene u tekućem razdoblju u odnosu na bazno razdoblje može se dobiti na sljedeći način:

$$S_t^* = I_t - 100$$

Prigodom izbora baznog razdoblja treba biti veoma obazriv jer se krivim izborom baznog razdoblja mogu dobiti pogrešne predodžbe o dinamici pojave. Odabere li se za bazno razdoblje takvo razdoblje u kojem je vrijednost pojave bila najmanja, dobit će se bazni indeksi koji uvijek pokazuju porast u odnosu na bazno razdoblje. Vrijedi i obrnuto. Slijedi da za bazno razdoblje treba odabrati ono koje je sa stajališta nastanka pojave normalno.

Indeksi na stalnoj bazi prikazuju se površinskim ili linijskim grafikonom. Razlika u prikazu indeksa i originalnog niza je u baznoj liniji. U prikazu indeksa pravokutnici se oslanjaju na baznu liniju, liniju 100, što nije slučaj s linijskim grafikonom niza.

4.7. Srednje vrijednosti¹⁸

Računanjem srednjih vrijednosti dolazi se do informacija o vrijednostima statističkog obilježja oko kojih se raspoređuju elementi statističkog niza. Srednja vrijednost je vrijednost statističkog obilježja oko koje se grupiraju podaci statističkog niza. Još se zove i "mjera centralne tendencije".

Srednje vrijednosti mogu se podijeliti na:

❖ **Položajne srednje vrijednosti** određuju se položajem podataka u nizu.

Najvažnije položajne srednje vrijednosti su :

a) mod,

b) medijan.

❖ **Potpune srednje vrijednosti** računaju se upotrebom svih podataka u statističkom nizu. To su:

a) aritmetička sredina,

b) harmonijska sredina,

¹⁸Rozga, A.: Statistika za ekonomiste, Ekonomski fakultet Split, Split, 2008., str. 37. - 46.

c) geometrijska sredina.

Mod

Mod je vrijednost statističkog obilježja koja se najčešće javlja u nekom nizu, tj. vrijednost obilježja kojoj pripada najveća frekvencija. Mod se može primijeniti na kvalitativne i kvantitativne statističke nizove, a spada u položajne srednje vrijednosti.

Kod nominalnih obilježja mod se određuje brojanjem, na način da se traži koja se vrijednost obilježja u nizu najčešće javlja. Ako je niz grupiran, traži se najveća apsolutna frekvencija. Vrijednost obilježja kojoj pripada ta najveća apsolutna frekvencija je mod.

Medijan

Medijan je vrijednost statističkog obilježja koja uređeni statistički niz dijeli na dva jednakobrojna dijela (u omjeru 1:1), odnosno 50% elemenata statističkog skupa ima vrijednost obilježja manju ili jednaku medijanu, a 50% elemenata statističkog skupa ima vrijednost obilježja veću od medijana.

Ako je niz sastavljen od neparnog broja elemenata onda je vrijednost medijana određena obilježjem jedinice u skupu koja se nalazi na polovini toga skupa. Ukoliko skup ima paran broj elemenata tada medijan definiraju sve vrijednosti obilježja između jedinice $(n/2)$ i $(n/2+1)$.

U statističkim distribucijama postoji samo jedan medijan i on se nalazi između najveće i najmanje vrijednosti obilježja. Njegova prednost je u tome što na njega ne utječu ekstremno male ili velike vrijednosti obilježja, pa je primjerena srednja vrijednost i kod izrazito asimetričnih distribucija.

Kvartili

Kvartili su vrijednosti statističkog obilježja koje uređeni statistički niz dijele na q jednakobrojnih dijelova. Kvartili su vrijednosti statističkog obilježja koje statistički niz dijele na 4 jednakobrojna dijela. Kvartili se mogu podijeliti na:

a) donji kvartil (Q_1)

b) gornji kvartil (Q_3)¹⁹.

Donji kvartil dijeli uređeni statistički niz na četiri jednaka dijela u omjeru 1:3, odnosno 25% elemenata statističkog skupa ima vrijednost obilježja manju ili jednaku donjem kvartilu, a 75% elemenata statističkog skupa ima vrijednost obilježja veću od donjeg kvartila. Gornji kvartil dijeli uređeni statistički niz na četiri jednaka dijela u omjeru 3:1, odnosno 75% elemenata statističkog skupa ima vrijednost obilježja manju ili jednaku donjem kvartilu, a 25% elemenata statističkog skupa ima vrijednost obilježja veću od gornjeg kvartila.

Računaju se sljedećim formulama:

Donji kvartil:

-za neparni broj članova niza

$$Q_1 = \{ x_r, \frac{n}{4} \neq INT, \quad r = INT\left(\frac{n}{4}\right) + 1$$

-za parni broj članova niza

$$Q_1 = \left\{ \frac{x_r + x_{r+1}}{2}, \quad \frac{n}{4} = INT, \quad r = \frac{n}{4} \right.$$

Gornji kvartil:

-za neparni broj članova niza

$$Q_3 = \{ x_r, \frac{3n}{4} \neq INT, \quad r = INT\left(\frac{3n}{4}\right) + 1$$

-za parni broj članova niza

$$Q_3 = \left\{ \frac{x_r + x_{r+1}}{2}, \quad \frac{3n}{4} = INT, \quad r = \frac{3n}{4} \right.$$

Aritmetička sredina

Ova najpoznatija srednja vrijednost omjer je zbroja svih vrijednosti numeričkog obilježja jednog niza i broja elemenata tog niza. Ako se radi o negrupiranom statističkom numeričkom

¹⁹ Vrijedi da je medijan: $Me = Q_2$

nizu računa se jednostavna aritmetička sredina. U slučaju grupiranog statističkog numeričkog niza računa se složena, vagana ili ponderirana aritmetička sredina.

U statističkoj analizi, ova srednja vrijednost najčešće se izračunava za vrijednosti numeričkog obilježja, pa je polazna veličina za izračunavanje aritmetičke sredine total. To je zbroj vrijednosti numeričkog obilježja elemenata osnovnog skupa. Za dobivanje aritmetičke sredine treba total jednako razdijeliti na svaki element osnovnog skupa.

Označimo li vrijednosti numeričkog obilježja sa $X_1, X_2, X_3, \dots, X_n$ onda se aritmetička sredina za n vrijednosti obilježja izračunava kao n -ti dio totala²⁰:

$$\bar{X} = \frac{X_1 + X_2 + X_3 + \dots + X_n}{n}.$$

Harmonijska sredina

Upotrebljava se rjeđe i to kod specifičnih slučajeva tj. u onim situacijama kada obilježja elemenata jednog skupa stoje u recipročnom odnosu s obilježjem elemenata nekog drugog skupa. Harmonijska sredina je recipročna vrijednost aritmetičke sredine recipročnih vrijednosti za koje se sredina izračunava.

Izračun je dan formulom:

$$X = \frac{n}{\frac{1}{X_1} + \frac{1}{X_2} + \frac{1}{X_3} + \dots + \frac{1}{X_n}}.$$

Geometrijska sredina

Geometrijska sredina n individualnih vrijednosti numeričke varijable X dana je ovim izrazom:

$$G = \sqrt[n]{X_1 * X_2 * X_3 * \dots * X_n}.$$

Primjenjuje se u analizi vremenskih nizova. Pomoću nje izračunava se prosječna stopa promjene pojave. Geometrijska sredina, kao i svaka srednja vrijednost, nalazi se između najveće i najmanje vrijednosti niza za koji se izračunava. Brojčano se razlikuje od aritmetičke sredine, osim ako svi članovi niza nisu jednaki. Geometrijska sredina je uvijek manja od aritmetičke.

²⁰ Rozga, A., Statistika za ekonomiste, Ekonomski fakultet Split, Split, 2005., str.39.-42.

4.8. Regresijska analiza

4.8.1. Dijagram rasipanja

U statističkim analizama često, uz analizu kretanja jedne pojave, postoji potreba istražiti ovisnosti dviju ili više pojava, odnosno numeričkih nizova, zajedno. Prvi korak u istraživanju ovisnosti varijabli je crtanje grafičkog prikaza koji se zove dijagram rasipanja. Dijagram rasipanja u pravokutnom koordinatnom sustavu točkama (x_i, y_i) prikazuje parove vrijednosti dviju promatranih numeričkih varijabli. Na osnovu dijagrama rasipanja se može zaključiti o postojanju, odnosno nepostojanju povezanosti pojava, obliku veze i smjeru i jakosti veze.

Koeficijent linearne korelacije iskazuje međuzavisnost ili povezanost slučajnih numeričkih varijabli. Po smjeru korelacija može biti pozitivna i negativna. Pozitivna korelacija je prisutna kada rast jedne varijable prati rast druge promatrane varijable, odnosno kada pad jedne prati pad druge varijable. Negativna korelacija prisutna je kada rast jedne varijable prati pad druge varijable i obratno. Najpoznatija mjera linearne korelacije između slučajnih varijabli je Pearsonov koeficijent linearne korelacije. Vrijednost koeficijenta linearne korelacije kreće se u intervalu: $-1 \leq r \leq 1$. U skladu s veličinom ovog koeficijenta može se zaključiti smjer i intenzitet linearne korelacije među promatranim varijablama²¹:

$r = -1; r = 1$: funkcionalna negativna/pozitivna korelacija

$-1 < r \leq -0,8$; $0,8 \leq r < 1$: jaka negativna/pozitivna korelacija

$-0,8 < r \leq -0,5$; $0,5 \leq r < 0,8$: srednje jaka negativna/pozitivna korelacija

$-0,5 < r < 0$; $0 < r < 0,5$: slaba negativna/pozitivna korelacija

$r = 0$: nema korelacije.

Testiranje hipoteze da je koeficijent korelacije jednak nuli

Da bi se izvršilo testiranje pretpostavke da je koeficijent korelacije jednak nuli postavlja se nulta hipoteza koja pretpostavlja da je vrijednost koeficijenta korelacije osnovnog skupa jednaka 0, tj. da ne postoji korelacija između slučajnih varijabli. Sampling distribucija

²¹ Rozga, A., Statistika za ekonomiste, Ekonomski fakultet Split, Split, 2006., str. 181.

koeficijenta korelacije za dovoljno veliki uzorak i za $r = 0$ ima oblik normalne distribucije, pa u ovom testiranju nisu potrebne nikakve transformacije.

$$H_0 \dots \dots \dots r = 0$$

$$H_1 \dots \dots \dots r \neq 0$$

Interval prihvatanja nulte hipoteze je:

$$0 \pm Z \cdot Se(r),$$

gdje standardna greška koeficijenta korelacije o ovisnosti o veličini uzorka n :

$$Se(r) = \sqrt{\frac{1}{n-1}}, n > 30$$

$$Se(r) = \sqrt{\frac{1-r^2}{n-2}}, n \leq 30$$

4.8.2. Jednostruka linearna regresija

U slučaju postojanja samo jedne ovisne ili regresand i samo jedne neovisne ili regresorske varijable kaže se da je to jednostavni, jednostruki ili jednodimenzionalni regresijski model, a regresijska analiza se može postaviti na sljedeći način²²:


1. Potpuno, precizno i koncizno definiranje predmeta i ciljeva istraživanja, te postavljanje osnovnih pretpostavki.
2. Crtanje dijagrama rasipanja, izbor modela i definiranje varijabli. Na primjer, aditivni model²³.
3. Odabir konkretnog regresijskog modela, njegova specifikacija i pretpostavke. (Na primjer, linearni model: $Y = \beta_0 + \beta_1 X + e$.)

²² Ibidem

²³ Modeli u praksi ne moraju biti aditivni: na primjer, multiplikativni model $Y = f(X) \cdot e$, gdje je: Y- ovisna ili regresand varijabla, X - neovisna ili regresorska varijabla, e – slučajna komponenta.

4. Statistička analiza modela: ocjena parametara i pokazatelja reprezentativnosti modela.
5. Testiranje hipoteza o modelu i statističko teorijskih pretpostavki.
6. a) DA - ako su ispunjene pretpostavke, vrši se sinteza rezultata i donose se sudovi o predmetu istraživanja.
- b) NE - ako nisu ispunjene pretpostavke: vrši se modifikacija modela i vraća se na korak 2., tj. na izbor novog modela i definiranje varijabli.

Dakle, regresijskom analizom traže se i ocjenjuju parametri funkcije koja na najbolji mogući način opisuje vezu između varijabli X i Y. Na temelju uzorka parova vrijednosti varijabli X i Y: $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ crta se dijagram rasipanja, koji je prikazan na slici 5.



Slika 5.: Dijagram rasipanja

Izvor: Pivac S.: Materijali s predavanja, Statističke metode, Ekonomski fakultet Split, 2009.

Testiranje hipoteze o značajnosti regresijskog modela kao cjeline

Nulta hipoteza pretpostavlja da su svi parametri regresijskog modela jednaki 0, dok alternativna hipoteza pretpostavlja da postoji barem jedan regresijski parametar različit od nule²⁴:

$$H_0 \dots \dots \beta_1 = \beta_2 = \dots = \beta_k = 0$$

$$H_1 \dots \dots \exists \beta_j \neq 0$$

²⁴ Rozga, A., Statistika za ekonomiste, Ekonomski fakultet Split, Split, 2006., str. 195.

Testiranje se vrši usporedbom empirijske i tablične vrijednosti F - testa. Empirijska vrijednost F -testa računa se pomoću podataka iz tablice analize varijance, tzv. tablice ANOVA:

| Izvor varijacije | Stupnjevi slobode | Zbroj kvadrata | Sredina kvadrata | Empirijski F-omjer |
|---------------------------------|-------------------|----------------|------------------|------------------------|
| Protumačeno modelom lin. reg. | k | SP | SP/k | $SP/k \div SR/n-(k+1)$ |
| Neprotumačeno modelom lin. reg. | $n-(k+1)$ | SR | $SR/n-(k+1)$ | . |
| ukupno | $n-1$ | ST | . | . |

Slika 6.: Opći oblik tablice ANOVA

Izvor: Ekonomski fakultet Sveučilišta u Zagrebu, nastavni materijali; dostupno na : <http://web.efzg.hr>

Gdje ako je $F^* > F_{\text{tabl}}$ prihvaća se alternativna hipoteza H_1 tj. zaključuje se da je ocijenjeni regresijski model statistički značajan.

4.9. Dummy varijable

Varijable koje se uključuje u regresijski model najčešće su numeričke varijable. Ponekad se u model pored numeričkih varijabli uključuje kvalitativne varijable. Kvalitativna varijabla u modelu se može pojaviti kao zavisna ili nezavisna varijabla. Regresijski model u kojem je zavisna varijabla numerička, a koji kao nezavisne varijable uz numeričke sadrži jednu ili više kvalitativnih varijabli, analizira se na jednak način kao i standardni regresijski model (modeli koji sadrže dummy varijablu kao zavisnu su logit i probit modeli).

Dummy varijabla u regresijskoj analizi je umjetno kontinuirana varijabla, čije se vrijednosti ne mogu numerički izraziti. Takva varijabla je najčešće rezultat postojanja ili nepostojanja nekog fenomena/događaja. Ako taj fenomen je postoji dummy varijabla poprima vrijednost 0, a ako taj fenomen postoji dummy varijabla poprima vrijednost 1.

Ponekad je moguće dummy varijabli dodijeliti i neke druge vrijednosti, npr. 0,25;0,5 i sl. Ako je u regresijski model potrebno uključiti više dummy varijabli, treba naglasiti da one nisu korelirane, pa stoga ne uvjetuju postojanje problema multikolinearnosti u regresijskom modelu.

Razlozi za uvođenje dummy varijabli kao regresorskih varijabli²⁵:

- uočavanje razlike u konstantnim članovima
- uočavanje razlike u nagibima regresijskih modela za različite kategorije kvalitativnih varijabli
- uočavanje sezonskih utjecaja
- iz numeričkih razloga, npr. ispitivanje stabilnosti parametara regresijskog modela i izračunavanje prognostičkih vrijednosti.

Za svaku kvalitativnu varijablu broj uvedenih dummy varijabli u model je za 1 manji od broja modaliteta promatrane varijable.

Postoje tri vrste Dummy varijabli: Dummy varijable konstantnog člana, Dummy varijable za promjene u nagibu i sezonske Dummy varijable.

Za ovo istraživanje korištena je Dummy varijabla za promjene u nagibu. Dummy varijable se u regresijske modele mogu uvesti i da bi se dozvolile promjene u nagibima. Ako su dvije regresijske jednadžbe za 2 modaliteta kvalitativne varijable²⁶:

$$\begin{aligned} Y_{i1} &= \beta_0^1 + \beta_1^1 X_{i1} + e_{i1} & i &= 1, 2, \dots, n_1 \\ Y_{i2} &= \beta_0^2 + \beta_1^2 X_{i2} + e_{i2} & i &= 1, 2, \dots, n_2 \end{aligned}$$

mogu se napisati:

$$\begin{aligned} Y_{i1} &= \beta_0^1 + (\beta_0^2 - \beta_0^1) \cdot 0 + \beta_1^1 X_{i1} + (\beta_1^2 - \beta_1^1) \cdot 0 + e_{i1} & i &= 1, 2, \dots, n_1 \\ Y_{i2} &= \beta_0^1 + (\beta_0^2 - \beta_0^1) \cdot 1 + \beta_1^1 X_{i1} + (\beta_1^2 - \beta_1^1) \cdot X_{i2} + e_{i2} & i &= 1, 2, \dots, n_2 \end{aligned}$$

tj.

$$Y_i = \beta_0^1 + (\beta_0^2 - \beta_0^1) \cdot D_1 + \beta_1^1 X_i + (\beta_1^2 - \beta_1^1) \cdot D_2 + e_i \quad i = 1, 2, \dots, n$$

gdje je:

$$D_1 = \begin{cases} 1 & \text{za mod 2} \\ 0 & \text{za mod 1} \end{cases}$$

²⁵ Pivac S.: Materijali s predavanja, Statističke metode, Ekonomski fakultet Split, 2009.

²⁶ Pivac S.: Materijali s predavanja, Statističke metode, Ekonomski fakultet Split, 2009.

$$D_2 = \begin{cases} X_2 & \text{za mod 2} \\ 0 & \text{za mod 1} \end{cases}$$

Parametar uz D1 mjeri razliku u konstantnim članovima, a parametar uz D2 mjeri razliku u nagibima. Ovdje vrijedi pretpostavka da su slučajne varijable u polaznim regresijskim modelima nezavisne i identično distribuirane.

Pri testiranju značajnosti regresijskog modela nulta hipoteza pretpostavlja da je parametar kojeg testiramo iz promatranog regresijskog modela jednak 0, tj. da nije statistički značajan, dok alternativna hipoteza pretpostavlja da je testirani regresijski parametar različit od nule, tj. da je statistički značajan²⁷:

$$H_0: \beta_j = 0$$

$$H_1: \beta_j \neq 0$$

Testiranje se vrši usporedbom empirijske i tablične vrijednosti t - testa.

Empirijska vrijednost t-testa računa se:

$$t^* = \frac{\hat{\beta}_j}{se(\hat{\beta}_j)}$$

gdje je:

$\hat{\beta}_j$ - vrijednost ocijenjenog parametra

$se(\hat{\beta}_j)$ - standardna greška ocijenjenog parametra, koja se izračunava:

$$se(\hat{\beta}_j) = \hat{\sigma}_{\hat{Y}} \cdot \sqrt{s_{jj}}$$

gdje s_{jj} predstavlja vrijednost odgovarajućeg dijagonalnog elementa u matrici $(X^T X)^{-1}$

Nulta hipoteza pretpostavlja da su svi parametri regresijskog modela jednaki 0, dok alternativna hipoteza pretpostavlja da postoji barem jedan regresijski parametar različit od nule²⁸:

$$H_0: \beta_1 = \beta_2 = \dots = \beta_k = 0$$

$$H_1: \exists \beta_j \neq 0 \quad j = 1, 2, \dots, k$$

²⁷ Pivac S.: Materijali s predavanja, Statističke metode, Ekonomski fakultet Split, 2009.

²⁸ Pivac S.: Materijali s predavanja, Statističke metode, Ekonomski fakultet Split, 2009.

Testiranje se vrši usporedbom empirijske i tablične vrijednosti F- testa. Empirijska vrijednost F-testa računa se pomoću podataka iz tablice analize varijance, tzv. tablice ANOVA.

Da bi se izvršilo navedeno testiranje pomoću veličina iz tablice ANOVA računa se empirijska i tablična vrijednost F-testa:

$$F^* = \frac{SP / k}{SR / (n - k - 1)},$$

koju je potrebno usporediti s tabličnom vrijednosti uz odgovarajuću razinu signifikantnosti α i stupnjevima slobode df_1 i df_2 .

Ako je:


$$F^* = \frac{SP / k}{SR / (n - k - 1)} < F_{tab} \Rightarrow H_0,$$

Prihvaća se hipoteza H_0 tj. zaključuje se da ocijenjeni regresijski model nije statistički značajan, dok se u suprotnom početna hipoteza odbacuje tj. zaključuje se da je ocijenjeni regresijski model statistički značajan.

5. POKAZATELJI TURISTIČKE DJELATNOSTI U SPLITSKO-DALMATINSKOJ ŽUPANIJI PREMA POPISIMA

Analiza kretanja turističkih pokazatelja kroz povijest ukazala je da je hrvatsko gospodarstvo prošlo kroz mnoga turbulentna razdoblja od osamostaljenja: kroz oporavak od rata, tranziciju te brojne reforme koje je karakterizirao pogrešan pristup. Sve to je ostavilo traga na mnoge sektore pa i turistički. Bilo je potrebno mnogo vremena da gospodarstvo postane zaista tržišno orijentirano. Svoj značajniji rast bilježi u razdoblju 2004.-2007. Nakon vrhunca u 2007. svjetska financijska kriza prodire i na naše tržište kapitala koje se počelo otvarati, usporava se gospodarska aktivnost, banke stežu plasmane i smanjuje se potrošnja, pada standard. Neki su sektori krizu osjetili više neki manje. Koliko se to odrazilo na turistički sektor kojeg karakterizira prelijevanje efekata krize emitivnih zemalja istražiti će se analizom trenda turističkih pokazatelja.


Nakon prezentacije kretanja u turističkom sektoru kroz povijest u nastavku će se prezentirati rezultati analize kretanja u turizmu u Splitsko – dalmatinskoj županiji od 2001. do 2013. Sa slike je vidljivo da u ukupnom broju turista najviše sudjeluju strani turisti. Trend kretanja ukupnog broja turista prati trend kretanja stranih turista. Uočava se rast sve do početka 2009. Nakon toga slijedi korekcija broja stranih turista koja se počinje oporavljati tek krajem 2010., da bi 2013. dosegla vrijednost značajno iznad one ostvarene u godini prije krize. Broj domaćih turista se neznatno povećao u istom periodu kad i broj stranih ali također dolazi do korekcije u godini krize. Nakon korekcije ostaje gotovo na ranijim razinama.



Slika 7: Kretanje broja dolazaka SD županija 2001.-2013.

Izvor: Na temelju statistika SD županije

Usporedba trenda broja noćenja na ukupnoj razini i prema kategoriji domaćih i stranih turista uočava se jednak trend. Ukupna noćenja uglavnom generiraju strani turisti. Kretanja u dvanaestogodišnjem periodu su prikazana na slici u nastavku.



Slika 8: Kretanje broja noćenja SD županija 2001.-2013.

Izvor: Na temelju statistika SD županije

U tablici u nastavku su prikazane srednje vrijednosti (aritmetička sredina, mod, minimum i maksimum) broja turista i noćenja. Može se reći da je prosječni desetogodišnji broj stranih turista 1358745, a najveći evidentirani broj noćenja 11467965. Najmanji broj domaćih turista

je u prosjeku 169301. Mod broja noćenja stranih turista iznosi 881605 što znači da je to u prosjeku najčešće ostvareni broj dolazaka tokom godina.

Tablica 1: Srednje vrijednosti izabranih varijabli

| | ukupan broj turista SD županije 2001.-2013. | broj domaćih turista SD županije 2001.-2013. | broj stranih turista SD županije 2001.-2013. | ukupan broj noćenja turista SD županije 2001.-2013. | broj noćenja domaćih turista SD županije 2001.-2013. | broj noćenja stranih turista SD županije 2001.-2013. |
|---------|---|--|--|---|--|--|
| Mean | 1562276,5385 | 203531,1538 | 1358745,3846 | 8597287,0769 | 811944,1538 | 7785342,9231 |
| Mode | 1050906,00(a) | 169301,00(a) | 881605,00(a) | 6075612,00(a) | 724492,00(a) | 5316001,00(a) |
| Minimum | 1050906,00 | 169301,00 | 881605,00 | 6075612,00 | 724492,00 | 5316001,00 |
| Maximum | 2037977,00 | 247989,00 | 1841665,00 | 11467965,00 | 983184,00 | 10694211,00 |

Izvor: Na temelju statistika TZ županije

Nakon prikaza kretanja dolazaka i noćenja tijekom vremena u nastavku su izračunati verižni i bazni indeksi. Cilj prikaza kretanja noćenja i broja dolazaka putem verižnih i baznih indeksa je uočiti razdoblja značajnijih oscilacija kako bi se ukazalo na moguće uzroke te ključna područja pri oblikovanju strategija.

U tablici 1 su dani verižni indeksi broja turista. Najveći indeks ukupnog broja turista je u 2007., kada iznosi 111,122 što znači da se broj turista u 2007. povećao za 11,122% u odnosu na godinu ranije.

Ako se promotre indeksi domaćih turista tada se uočava njihov najveći pad ostvaren u 2009., kada iznosi 90,599% što znači da je se broj domaćih turista smanjio za oko 9,5% u odnosu na godinu ranije. Analiza verižnih indeksa stranih turista ukazuje da je pad evidentan svega u dvije godine (2009. i 2010.). Smanjenje stranih turista je manje nego domaćih.

Tablica 2.: Verižni indeksi broja turista SD županije 2001.-2013.

| godina | broj turista | domaći | strani | Vt ukupno | Vt domaći | Vt strani |
|--------|--------------|--------|---------|------------|--------------|-----------|
| 2001. | 1050906 | 169301 | 881605 | | | |
| 2002. | 1177142 | 181095 | 996047 | 112,981097 | 106,9663 | 112,0121 |
| 2003. | 1236570 | 187113 | 1049457 | 105,362197 | 103,3231 | 105,0485 |
| 2004. | 1366950 | 196704 | 1170246 | 111,509666 | 105,1258 | 110,5437 |
| 2005. | 1505266 | 205618 | 1299648 | 111,057675 | 104,5317 | 110,1186 |
| 2006. | 1549257 | 214639 | 1334618 | 102,690729 | 104,3873 | 102,9225 |
| 2007. | 1731039 | 247989 | 1483050 | 111,121684 | 115,5377 | 111,7335 |
| 2008. | 1746311 | 235765 | 1510546 | 101,854017 | 95,07075 | 100,8822 |
| 2009. | 1657945 | 213475 | 1444470 | 95,6256877 | 90,54567 | 94,93985 |
| 2010. | 1637656 | 199811 | 1437845 | 99,5413543 | 93,59925 | 98,77626 |
| 2011. | 1777700 | 206095 | 1571605 | 109,302811 | 103,145 | 108,5515 |
| 2012. | 1834876 | 191988 | 1642888 | 104,535682 | 93,1551 | 103,2163 |
| 2013. | 2037977 | 196312 | 1841665 | 112,099242 | 102,2522 | 111,0689 |

Izvor: Na temelju statistika SD županije

Verižni indeksi broja noćenja ukazuju na nešto manje dramatičnu korekciju jer je indeks ispod sto evidentiran u manjem broju slučajeva, dok je kod stranih turista to bilo u samo jednoj godini (2009.) nakon koje slijedi ponovni rast. 2007. je ponovno godina najvišeg uzleta turizma. Posljedica toga jest veći dio stranih turista u kreiranju broja noćenja.

Tablica 3: Verižni indeksi broja noćenja turista

| godina | broj noćenja | domaći | strani | Vt ukupno | Vt domaći | Vt strani |
|--------|-----------------|--------|----------|------------|--------------|-----------|
| 2001. | 6075612 | 759611 | 5316001 | | | |
| 2002. | 6478955 | 729577 | 5749378 | 108,152312 | 96,04613 | 106,6387 |
| 2003. | 6656142 | 736032 | 5920110 | 102,969573 | 100,8848 | 102,7348 |
| 2004. | 7018491 | 724492 | 6293999 | 106,315575 | 98,43213 | 105,4438 |
| 2005. | 8028642 | 804837 | 7223805 | 114,772897 | 111,0898 | 114,3927 |
| 2006. | 8345964 | 873731 | 7472233 | 103,439019 | 108,56 | 103,9524 |
| 2007. | 9246960 | 983184 | 8263776 | 110,593125 | 112,5271 | 110,7956 |
| 2008. | 9325458 | 897164 | 8428294 | 101,990833 | 91,25087 | 100,8489 |
| 2009. | 8988416 | 833314 | 8155102 | 96,7586323 | 92,88313 | 96,38579 |
| 2010. | 9364032 | 805387 | 8558645 | 104,94835 | 96,64868 | 104,1789 |
| 2011. | 10250215 | 859886 | 9390329 | 109,717473 | 106,7668 | 109,4637 |
| 2012. | 10517880 | 774305 | 9743575 | 103,761806 | 90,0474 | 102,6113 |
| 2013. | 11467965 | 773754 | 10694211 | 109,756542 | 99,92884 | 109,033 |

Izvor: Na temelju statistika SD županije

Analiza baznih indeksa ukazuje na trend rasta broja dolazaka turista u razdoblju uzleta gospodarstva (2006.-2008.) ali i na korekciju broja domaćih turista u godinama krize. Broj stranih turista je nastavio rast što ukazuje na veću osjetljivost potražnje domaćih turista u odnosu na strane. Za baznu godinu je uzeta 2009.

Tablica 4: Bazni indeksi broja noćenja, 2009.= 100

| godina | broj noćenja | domaći | strani | It ukupno | It domaći | It strani |
|--------|--------------|--------|----------|------------|-----------|-----------|
| 2001. | 6075612 | 759611 | 5316001 | 67,5938007 | 91,15543 | 65,1862 |
| 2002. | 6478955 | 729577 | 5749378 | 72,0811654 | 87,55127 | 70,50038 |
| 2003. | 6656142 | 736032 | 5920110 | 74,0524471 | 88,32589 | 72,59394 |
| 2004. | 7018491 | 724492 | 6293999 | 78,0837358 | 86,94106 | 77,17867 |
| 2005. | 8028642 | 804837 | 7223805 | 89,3221008 | 96,58268 | 88,58019 |
| 2006. | 8345964 | 873731 | 7472233 | 92,8524447 | 104,8502 | 91,62648 |
| 2007. | 9246960 | 983184 | 8263776 | 102,876413 | 117,9848 | 101,3326 |
| 2008. | 9325458 | 897164 | 8428294 | 103,749737 | 107,6622 | 103,35 |
| 2009. | 8988416 | 833314 | 8155102 | 100 | 100 | 100 |
| 2010. | 9364032 | 805387 | 8558645 | 104,17889 | 96,64868 | 104,9484 |
| 2011. | 10250215 | 859886 | 9390329 | 114,038057 | 103,1887 | 115,1467 |
| 2012. | 10517880 | 774305 | 9743575 | 117,015946 | 92,91876 | 119,4783 |
| 2013. | 11467965 | 773754 | 10694211 | 127,586051 | 92,85263 | 131,1352 |

Izvor: Na temelju statistika SD županije

Nakon prezentacije kretanja broja dolazaka i broja noćenja izračunat je trend kretanja broja turista. Jednadžba koja definira odnos zavisne varijable (broj turista) o varijabli vremena je jednostruka linearna regresija u kojoj broj turista predstavlja zavisnu, a vrijeme nezavisnu varijablu. Cilj tog modela jest procjena broja dolazaka turista u nekom budućem vremenu. Oblik jednadžbe se može zapisati kao:


$$Y_{(\text{broj turista})} = B_0 + B \cdot X_{t(\text{vrijeme})}$$

Na temelju podataka o broju turista te definiranjem vremena s ishodištem trenda na početku razdoblja izračunat je trend model. Dijagram i jednadžba trenda dani su na slici 9. Sa slike se uočava da je izrađen linearni trend model s ishodištem na početku razdoblja. Na temelju predznaka izračunatog koeficijenta uz nezavisnu varijablu (+) uočava se da se kroz vrijeme broj turista povećava. Iz dobivene jednadžbe trenda na temelju podataka o konstantnom članu

(B_0) i koeficijenta uz nezavisnu varijablu (B_1) uočava se da se broj turista povećava godišnje u prosjeku za 189.079. U skladu s time može se izračunati da se, ukoliko se nastavi uočeni trend, u 2020. može očekivati oko 3.592.520 turista.

Izračun očekivanog broja turista je dobiven je uvrštavanjem vrijednosti vremenskog razdoblja u jednadžbu na mjesto nezavisne varijable te se izračun može iskazati kao:


$$\hat{y} = 189079x + 19$$



Slika 9: Trend model broja turista

Izvor: Na temelju statistika SD županije

Koji faktori utječu na turistički sektor kroz stavku prihoda od turizma vidljivo je sa slike u nastavku. Niža stopa inflacije čini destinaciju SD županije jeftinijom te privlačnijom turistima to pozitivno djeluje na akumulaciju deviznih prihoda od turizma koji upravo u razdoblju smanjenja inflacije bilježe rast. Sa grafičkog prikaza se uočava i to da su prihodi korekciju zabilježili godinu ranije. Razlog tome je razvoj krize na emitivnim tržištima nešto ranije nego u nas što je uz određenu prisutnost inflacije dovelo do smanjenje prihoda. Broj turista kroz godine raste osim pada u doba kada je nastupila kriza ali od tada se također počinje penjati broj dolazaka.



Slika 10: Kretanje inflacije i deviznog prihoda turizma

Izvor: Na temelju statistika SD županije

Prihod od turizma između 2001. i 2011. godine raste sve dok nije nastupila kriza i tada dolazi do pada deviznog prihoda.

Za kraj je izrađen višestruki regresijski model koji opisuje ovisnost varijable broja noćenja stranih turista u SD županiji o inflaciji, tečaju i krizi. Rezultati modela su dani u nastavku. U tablici 5 se može iščitati da je stupanj determinacije modela 0,856 tj. 85,6% što znači da se 85,6% promjena zavisne varijable može objasniti kao posljedica kretanja nezavisnih varijabli. Uočena determinacija ukazuje na visoku protumačenost u modelu. U tablici je dan rezultat Durbin Watson testa koji iznosi 1,504 što je blizu dva te označava stoga da se u modelu ne javlja problem autokorelacije reziduala dajući veći značaj modelu.

Tablica 5: Stupanj determinacije modela

| Model | R | R Square | Adjusted R Square | Std. Error of the Estimate | Durbin-Watson |
|-------|---------|----------|-------------------|----------------------------|---------------|
| 1 | ,925(a) | ,856 | ,774 | 694387,00230 | 1,504 |

a Predictors: (Constant), kriza, inflacija, tečaj EUR, tečaj USD

b Dependent Variable: broj noćenja stranih turista SD županije 2001.-2013.

Izvor: Na temelju statistika SD županije

Na temelju F testa značajnosti modela kao cjeline uočava se da je empirijska signifikantnost 0,005 tj. 0,5% što je ispod uvjetne vrijednosti značaja od maksimalnih 5% te se zaključuje da je model statistički značajan.

Tablica 6: F test značajnosti modela kao cjeline

| Model | | Sum of Squares | df | Mean Square | F | Sig. |
|-------|------------|----------------|----|-------------|--------|---------|
| 1 | Regression | 200666819 | 4 | 50166704948 | 10,404 | ,005(a) |
| | | 79241,240 | | 10,310 | | |
| | Residual | 337521316 | 7 | 48217330895 | | |
| | | 2714,995 | | 9,285 | | |
| Total | | 234418951 | 11 | | | |
| | | 41956,240 | | | | |

a Predictors: (Constant), kriza, inflacija , tečaj EUR, tečaj USD

b Dependent Variable: broj noćenja stranih turista SD županije 2001.-2013.

Izvor: Na temelju statistika SD županije

Rezultati u tablici koeficijenata ukazuju na to da viši tečaj eura ili dolara imaju s porastom negativan efekt na broj noćenja stranih turista. To znači da s jačanjem kune dolazi do pada broja noćenja jer strancima kupnju domaće valute čini skupljom. Koeficijent uz varijablu inflacije također ima negativni predznak što znači da se s rastom inflacije smanjuje broj noćenja i obratno. Na temelju VIF i TOL pokazatelja inflacije modela se zaključuje da se u modelu ne javlja problem multikolinearnosti jer je pokazatelj tolerance iznad 20%, a VIF ispod 5.

Tablica 7: Koeficijenti nezavisnih varijabli modela


| Model | | Unstandardized Coefficients | | Standardized Coefficients | t | Sig. | Collinearity Statistics | |
|-------|------------|-----------------------------|--------------|---------------------------|--------|------|-------------------------|-------|
| | | B | Std. Error | Beta | | | Tolerance | VIF |
| 1 | (Constant) | -9297610,584 | 18472167,069 | | -,503 | ,630 | | |
| | tečaj EUR | 2658586,591 | 2544075,420 | ,185 | 1,045 | ,331 | ,653 | 1,531 |
| | tečaj USD | -554225,074 | 307019,312 | -,399 | -1,805 | ,114 | ,420 | 2,380 |
| | inflacija | -115762,109 | 171503,407 | -,110 | -,675 | ,521 | ,768 | 1,303 |
| | kriza | 1870381,157 | 598399,738 | ,669 | 3,126 | ,017 | ,449 | 2,228 |
| | | | | | | | | |

a Dependent Variable: broj noćenja stranih turista SD županije 2001.-2013.

Izvor: Na temelju statistika SD županije

Pri izračunu krize se koristio broj 1 u godinama u kojima je bilo krize a dok krize nije bilo uzeta je vrijednost 0.

Na slici u nastavku se uočava disperzija što je odraz stupnja determinacije modela. Vidljivo je da se opažanja zavisne varijable nalaze gotovo na pravcu. To potvrđuje zaključak o visokoj objašnjenosti modela.



Slika 11: Dijagram rasipanja

Izvor: Na temelju statistika SD županije

Potonji model je ukazao da tečaj pogoduje prometu u turizmu ali isto tako da inflacija negativno djeluje na turističku potražnju. Upravljanje tečajem te definiranje cijena turističkih proizvoda i usluga ključ su prodaje u turizmu uz prezentaciju destinacije.

Nakon analize određenih faktora koji determiniraju turističke pokazatelje u nastavku je kroz izrađeni model istražen utjecaj efekata turističkog sektora na gospodarstvo na makro razini. Za zavisnu varijablu uzet je bruto domaći proizvod, a nezavisne inflacija, nezaposlenost, devizni prihod od turizma te direktne investicije u turizam. Model karakterizira iznimno visok stupanj determinacije od 97% Vrijednost DW testa značajno ne prelazi kritičnu granicu od 2 stoga ga ne karakterizira problem autokorelacije reziduala.

Tablica 8: Stupanj determinacije modela

| Model | R | R Square | Adjusted R Square | Std. Error of the Estimate | Durbin-Watson |
|-------|---------|----------|-------------------|----------------------------|---------------|
| 1 | ,985(a) | ,970 | ,946 | 13814351370 ,03372 | 2,346 |

a Predictors: (Constant), devizni PH turizam, FDI u turizam u mil kn, inflacija , nezaposlenosti

b Dependent Variable: BDP

Izvor: Na temelju statistika SD županije

Model kao cjelina je statistički značajan što je dokazano F testom. Empirijska razina signifikantnosti iznosi oko 0,1% što je ispod uvjetne maksimalne vrijednosti značaja od 5%.

Tablica 9: F test značajnosti modela kao cjeline

| Model | | Sum of Squares | df | Mean Square | F | Sig. |
|-------|------------|-------------------------------------|----|------------------------------------|--------|---------|
| 1 | Regression | 311011312 436262400 00000,000 | 4 | 77752828109 06560000000, 000 | 40,743 | ,001(a) |
| | Residual | 954181518 873761000 000,000 | | 19083630377 4752300000,0 00 | | |
| | Total | 320553127 625000000 00000,000 | 9 | | | |

a Predictors: (Constant), devizni PH turizam, FDI u turizam u mil kn, inflacija , nezaposlenosti

b Dependent Variable: BDP

Izvor: Na temelju statistika SD županije

Na temelju rezultata o VIF i TOL pokazateljima zaključuje se i to da se u modelu ne javlja problem multikolinearnosti nezavisnih varijabli jer su vrijednosti pokazatelja inflacije modela iznad odnosno ispod uvjetnih vrijednosti za postojanje tog problema. Na temelju signifikantnosti svakog od koeficijenata nezavisnih varijabli se uočava da su kao samostalne statistički značajne upravo direktne investicije u sektor turizma (4,3%) i prihod od turizma (0,5%). Upravo te varijable imaju pozitivan utjecaj na gospodarstvo tj. na stvaranje dodane vrijednosti kroz doprinos BDP-u, dok nezaposlenost i inflacija s rastom vode opadanju BDP-a. Relativni utjecaj direktnih investicija u turizam je 0,208, a deviznog prihoda 0,659. Slabiji utjecaj investicija leži u činjenici djelovanja svih efekata ulaganja s vremenskim pomakom. Ulaganja luče efekte kroz dugogodišnji period, a ostvarenih prihod kratkoročni.

Tablica 10: Koeficijenti nezavisnih varijabli modela

| Model | | Unstandardized Coefficients | | Standardized Coefficients | t | Sig. | Collinearity Statistics | |
|-------|------------------------|-----------------------------|------------|---------------------------|-------|------|-------------------------|-------|
| | | B | Std. Error | Beta | | | Tolerance | VIF |
| 1 | (Constant) | 235678 | 713785 | | | | | |
| | | 626215,074 | 08423,702 | | 3,302 | ,021 | | |
| | FDI u turizam u mil kn | 315249 | 123021 | | | | | |
| | | 398,840 | 470,614 | ,208 | 2,563 | ,043 | ,905 | 1,105 |
| | devizni PH | 163028 | 343416 | | | | | |
| | turizam | 16,678 | 4,900 | ,659 | 4,747 | ,005 | ,309 | 3,237 |

a Dependent Variable: BDP

Izvor: Na temelju statistika SD županije

Na posljetku se testiralo postojanje problema heteroskedastičnosti koji se računa testiranjem postojanja korelacije apsolutnih reziduala i nezavisnih varijabli. Da bi model dodatno dobio na reprezentativnosti potrebno je da su varijance nepromjenjive tj. da korelacija apsolutnih reziduala i nezavisnih varijabli nije statistički značajna. Rezultati testa su dani u tablici u nastavku. Na temelju empirijske signifikantnosti koeficijenata korelacije apsolutnih reziduala i nezavisnih varijabli se zaključuje da niti jedan koeficijent korelacije nije statistički značajan jer im signifikantnost prelazi maksimalnu uvjetnu vrijednost značaja od 5%. Može se reći da prezentirani model ne karakterizira ni problem heteroskedastičnosti.

Tablica 11: Test heteroskedastičnosti - korelacija apsolutnih reziduala i nezavisnih varijabli

| | | inflacija | nezaposlenosti | FDI u turizam u mil kn | devizni PH turizam | absres |
|------------------------|---------------------|-----------|----------------|------------------------|--------------------|--------|
| inflacija | Pearson Correlation | 1 | ,107 | -,040 | -,277 | ,062 |
| | Sig. (2-tailed) | | ,741 | ,912 | ,409 | ,848 |
| | N | 13 | 12 | 10 | 11 | 12 |
| nezaposlenosti | Pearson Correlation | ,107 | 1 | -,284 | -,799(**) | ,032 |
| | Sig. (2-tailed) | ,741 | | ,427 | ,003 | ,922 |
| | N | 12 | 12 | 10 | 11 | 12 |
| FDI u turizam u mil kn | Pearson Correlation | -,040 | -,284 | 1 | ,176 | -,291 |
| | Sig. (2-tailed) | ,912 | ,427 | | ,626 | ,415 |
| | N | 10 | 10 | 10 | 10 | 10 |
| devizni PH turizam | Pearson Correlation | -,277 | -,799(**) | ,176 | 1 | ,172 |
| | Sig. (2-tailed) | ,409 | ,003 | ,626 | | ,612 |
| | N | 11 | 11 | 10 | 11 | 11 |
| absres | Pearson Correlation | ,062 | ,032 | -,291 | ,172 | 1 |
| | Sig. (2-tailed) | ,848 | ,922 | ,415 | ,612 | |
| | N | 12 | 12 | 10 | 11 | 12 |

** Correlation is significant at the 0.01 level (2-tailed).

Izvor: Na temelju statistika SD županije

Model efekata turističkog sektora na makro razini je ukazao na značajan utjecaj direktnih investicija turizma na stvaranje dodane vrijednosti i rast BDP-a. Uloga investicija se temelji na sinergijskim efektima koje one stvaraju aktivirajući ostale sektore (izgradnja hotela aktivira građevinarski sektor, prezentacija domaćih proizvoda razvoja proizvodnih industrija zemlje i sl.). Stoga turistički sektor i ministarstva te Vlada moraju nastojati harmonizirati strategije kako bi se gospodarstvo pokrenulo te okrenulo pozitivnim brojkama zahvaljujući turističkom sektoru, kao izvoznoj industriji i generatoru vanjskog kapitala, ali i ostalim sektorima te se ostvario održivi razvoj koji će jačati komparativne prednosti destinacije i čitavog gospodarstva.

6. ZAKLJUČAK

Turistički sektor je iznimno važan za hrvatsko gospodarstvo ali ni slučajno se ne smije dozvoliti dosadašnji tretman ulaganja. Važno je da se potaknu ulaganja u održavanje standarda i kvalitete infrastrukture koja je osnova turističke djelatnosti poput (kvalitete prometne infrastrukture, prometne povezanosti, smještajnih kapaciteta i sl.) ali i da se razvojem novih turističkih proizvoda i selektivnih oblika smanji izrazita sezonalnost ovog sektora. Na taj će se način osigurati stabilniji priljev stranih sredstava tj. kapitala ali i direktnih stranih investicija u gospodarstvo. Rast generiran turističkim vidom izvoza osigurat će smanjenje deficita platne bilance i omogućiti dodatna zapošljavanja koja neće biti sezonskog karaktera što bi utjecalo na pad stope nezaposlenosti. Pokretanjem turističkog sektora za koji imamo prirodne predispozicije kao destinacija bi se osjetili dugoročni pozitivni efekti na rast ostalih vezanih sektora ali i povećala bi se potreba za različitim profilima kadra što bi donijelo i pozitivne promjene u obrazovnom sustavu.

Turizam je važna gospodarska grana koja je dobila obilježja industrije izvoznika i najboljeg promotora neke zemlje u svijetu. Kvalitetna promocija vodi i razvoju dobrih odnosa sa drugim zemljama, jačanju diplomatskih odnosa i razvoju novih partnera.

Prezentacijom teorijskih dostignuća definirana je uloga turizma, kao sektora koji osigurava sinergijske efekte te omogućuje razvoj čitavog gospodarstva kako na makro tako i na mikro razini. U tu su svrhu analizirana kretanja broja dolazaka i broja noćenja tijekom vremena (2000.-2014.). Cilj opisane analize je definiranje trendova turističkog sektora kako bi se ispitala osjetljivost turizma na krizu te efekata turističkog sektora na ostale gospodarske sektora i gospodarstvo kao cjelinu. Analiza trenda i izračunati ukazali su da je turistički sektor, usprkos visokoj snazi i sredstvima koje on generira iz emitivnih zemalja. Rezultati su ukazali da su se posljedice krize u turističkom sektoru osjetile svega kroz godinu krize 2008./2009. što je obilježeno korekcijama broja dolazaka i noćenja. Analiza rezultata je ukazala na snagu turističkog sektora u nas. Korekcije u prometu i broju dolazaka i noćenja nisu toliko velike te se očituju kroz dvije godine. Oporavak ukupnog prometa je uslijedio već godinu nakon najvećeg udara krize (2009.-godina najvećeg pritiska krize, 2010. sektor započinje oporavak). Regresijski modeli su ukazali na značajan doprinos turističkog sektora ukupnom gospodarstvu te potencijal ulaganja i razvoja u isti. To je vidljivo kroz efekte investicija u turizma na kretanje broja dolazaka i noćenja ali i utjecaja investicija na ukupno

gospodarstvo preko BDP-a. Vrijednosti i predznaci koeficijenata uz nezavisne varijable u regresijskim modelima koji su definirali utjecaj turističkog sektora na gospodarstvo ukazuju da kriza ima negativan utjecaj dok investicije u turistički sektor pozitivan. Na temelju toga se zaključuje da su ulaganja ključ održavanja standarda kvalitete ali i diferenciranja i razvoja ponude koja će osigurati višu razinu konkurentnosti. Ulaganja se mogu realizirati projektima. Da bi ulaganja rezultirala uočenim efektima važno je oblikovati adekvatne strategije i selektirati prave projekte stoga je važno je osigurati i kvalitetan monitoring za evaluaciju aktivnosti i praćenje kretanja turističkog sektora kako bi se osigurala ocjena efektivnosti i efikasnosti provedenih projekata i aktiviranih mjera za unaprjeđenje standarda turizma te repozicioniranje hrvatske na globalnom turističkom tržištu općenito ali i njezinih pojedinih dijelova. Nužna je suradnja područja destinacije (na nacionalnoj razini) kako bi se iskoristili efekti suradnje te smanjili efekti konkuriranja pojedinih dijelova iste destinacije. Cilj je ukupni razvoj turističkog sektora i razvoj održivog rasta temeljenog na prednostima u područjima gdje imamo perspektive upravo za to (očuvana priroda i krajolik, autohtoni proizvodi, bogata baština i sl.). Kvalitetnim strategijama će se osigurati razvoj svih dijelova hrvatske od ruralnih do područja otoka.

Iz svih pokazatelja možemo zaključiti da je turizam važna gospodarska grana u Hrvatskoj i da može biti nositelj razvoja jer broj dolazaka turista i prihod od turizma između 2001. i 2011. godine konstantno raste osim u godini krize a čak i tada je oporavak bio brz.

SAŽETAK

Turistički sektor je iznimno važan za hrvatsko gospodarstvo. Važno je da se potaknu ulaganja u održavanje standarda i kvalitete infrastrukture koja je osnova turističke djelatnosti . Rast generiran turističkim vidom izvoza osigurat će smanjenje deficita platne bilance i omogućiti dodatna zapošljavanja koja neće biti sezonskog karaktera što bi utjecalo na pad stope nezaposlenosti. Analiza rezultata je ukazala na snagu turističkog sektora u nas. Korekcije u prometu i broju dolazaka i noćenja nisu toliko velike te se očituju kroz dvije godine. Oporavak ukupnog prometa je uslijedio već godinu nakon najvećeg udara krize.

Ključne riječi: turizam, Splitsko-dalmatinska županija, gospodarski rast

SUMMARY

The tourism sector is extremely important for the Croatian economy. It is important to encourage investment in the maintenance of standards and quality of infrastructure that is main condition for tourism activity. The growth generated by tourism as the industry with the aspect of export will ensure reduction in the current account deficit and provide additional employment that will be seasonal characteristics which would affect the decline in the unemployment rate. Analysis of the results indicated the strength of the tourism sector in the Split-Dalmatia county. Corrections in traffic and the number of arrivals and overnight stays are not so bad. Recovery of total traffic followed the year after the impact of the crisis.

Keywords: tourism, Split-Dalmatia county, economic growth

LITERATURA

Knjige i nastavni materijali

1. Grčić, B.: Poslovna statistika u Microsoft Excelu, Ekonomski fakultet Split, 2004.
2. Lickorish, L., J., Uvod u turizam, Ekokon , Split, 2006.
3. Petrić, L., Osnove turizma, Ekonomski fakultet Split, Split, 2003.
4. Pirjevac B., Ekonomska obilježja turizma, Golden marketing, Zagreb, 1998.
5. Pivac S.: Materijali s predavanja, Statističke metode, Ekonomski fakultet Split, 2009.
6. Rozga, A.: Statistika za ekonomiste, V. Izdanje, Ekonomski fakultet Split, 2009.
7. Rozga, A., Grčić, B.: Poslovna statistika, Ekonomski fakultet u Splitu, 2009.
8. Zelenika, R.: Metodologija i tehnika izrade znanstvenog i stručnog djela, IV. Izdanje, Ekonomski fakultet u Rijeci, Rijeka, 2000.
9. Čizmešija, M., Kurnoga Živadinović; N.: Uvod u gospodarsku statistiku, Element, Zagreb, 2012.
10. Šošić, I.: Statistika, Školska knjiga, Zagreb, 2006.
11. Šošić, I.: Metode statističke analize, Ekonomski fakultet, Zagreb, 1991.
12. Šošić, I.: Primijenjena statistika, Školska knjiga, 2. Izdanje, Zagreb, 2006.
13. Pauše, Ž.: Uvod u matematičku statistiku, Školska knjiga, Zagreb, 1993.
14. Bahovec, V., Eljavec, N.: Uvod u ekonometrijsku analizu, Element, Zagreb, 2009.

Internet

15. www.dzs.hr
16. www.mint.hr
17. www.dalmatia.hr
18. <http://bist.iztztg.hr/bist/login.asp>

Popis slika

| | |
|---|----|
| Slika 1: Broj turista u nekim primorskim mjestima 1897. i 1910. godine..... | 10 |
| Slika 2: Turistički promet u Hrvatskoj 1938.godine | 11 |
| Slika 3: Kretanje registriranog turističkog prometa u RH 1960.-2001. | 12 |
| Slika 4: Dolasci turista u RH u razdoblju od 1975. do 2009. godine | 13 |
| Slika 5.: Dijagram rasipanja..... | 26 |
| Slika 6.: Opći oblik tablice ANOVA..... | 27 |
| Slika 7: Kretanje broja dolazaka SD županija 2001.-2013..... | 32 |
| Slika 8: Kretanje broja noćenja SD županija 2001.-2013..... | 32 |
| Slika 9: Trend model broja turista..... | 36 |
| Slika 10: Kretanje inflacije i deviznog prihoda turizma..... | 37 |
| Slika 11: Dijagram rasipanja..... | 39 |

Popis tablica

| | |
|--|----|
| Tablica 1: Srednje vrijednosti izabranih varijabli | 33 |
| Tablica 2.: Verižni indeksi broja turista SD županije 2001.-2013..... | 34 |
| Tablica 3: Verižni indeksi broja noćenja turista | 34 |
| Tablica 4: Bazni indeksi broja noćenja, 2009.= 100 | 35 |
| Tablica 5: Stupanj determinacije modela | 37 |
| Tablica 6: F test značajnosti modela kao cjeline..... | 38 |
| Tablica 7: Koeficijenti nezavisnih varijabli modela..... | 38 |
| Tablica 8: Stupanj determinacije modela | 40 |
| Tablica 9: F test značajnosti modela kao cjeline..... | 40 |
| Tablica 10: Koeficijenti nezavisnih varijabli modela..... | 41 |
| Tablica 11: Test heteroskedastičnosti - korelacija apsolutnih reziduala i nezavisnih varijabli | 42 |
| Tablica 12: Baza podataka gospodarstva..... | 49 |

PRILOG

Tablica 12: Baza podataka gospodarstva

| god. | EUR | USD | inflacija | saldo platne bilance | nezaposlenost | FDI turizma | devizni prihod turizma |
|-------|------|------|-----------|----------------------------|---------------|----------------|------------------------------|
| 2001. | 7,47 | 8,34 | 4 | -1429 | 19,1 | 28,5 | 2758 |
| 2002. | 7,41 | 7,87 | 4,8 | -568 | 21,1 | 62 | 3335 |
| 2003. | 7,56 | 6,7 | 4,6 | -821 | 22 | 27 | 3811,5 |
| 2004. | 7,5 | 6,03 | 3,8 | -2099 | 22,3 | 92,4 | 4788 |
| 2005. | 7,4 | 5,95 | 1,7 | -1889 | 19,2 | 16,7 | 5516 |
| 2006. | 7,32 | 5,84 | 1,8 | -1434 | 18 | 39,7 | 6616,2 |
| 2007. | 7,34 | 5,37 | 2,1 | -1976 | 17,9 | 91,7 | 7253,5 |
| 2008. | 7,22 | 4,93 | 3,3 | -2717 | 16,6 | 29,4 | 8248 |
| 2009. | 7,34 | 5,28 | 3,2 | -3238 | 14,8 | 32,7 | 10167,5 |
| 2010. | 7,29 | 5,5 | 2,9 | -4369 | 13,2 | 137,5 | 7979,4 |
| 2011. | 7,43 | 5,34 | 6,4 | . | 14,4 | . | 7225,9 |
| 2012. | 7,52 | 5,85 | 2,4 | . | 15 | . | . |
| 2013. | 7,57 | 5,71 | 2 | . | . | . | . |

Izvor: DZS, HNB